

BAB II TINJAUAN PUSTAKA

2.1 Kajian Relevan

Tinjauan pustaka ini memuat telaah atas berbagai karya ilmiah pendahulu yang memiliki relevansi, baik dari segi substansi topik maupun pendekatan metodologis yang digunakan. Langkah ini krusial untuk melacak tren riset terkini seputar analisis sentimen, mengidentifikasi ragam metode yang pernah diaplikasikan, menyandingkan temuan-temuan sebelumnya, sekaligus memetakan celah penelitian (*research gap*) yang mendasari pelaksanaan studi ini. Secara spesifik, literatur yang dikaji berpusat pada pemanfaatan algoritma Naïve Bayes, Multinomial Naïve Bayes, pembobotan TF-IDF, serta model bahasa IndoBERTacross berbagai domain, mulai dari ulasan produk digital, dinamika media sosial, layanan *e-commerce*, hingga diskursus kebijakan publik.

Tabel 2. 1 Penelitian Terdahulu

N o	Penulis (Tahun)	Judul Penelitian	Metode	Hasil Penelitian	Relevansi dengan Penelitian
1	Hidayah, Kusumawati, Abidin, & Imamuddin (2024)	Analysis of Public Sentiment Towards The TikTok Application Using The Naive Bayes Algorithm and Support Vector Machine	TF-IDF, Naïve Bayes, SVM	Naïve Bayes memperoleh akurasi 79%, sedangkan SVM mencapai 84%.	Menunjukkan bahwa TF-IDF efektif digunakan sebagai representasi fitur dan Naïve Bayes mampu mengklasifikasik an sentimen berbahasa Indonesia.

2	Hilmi & Irwiensyah (2024)	Sentiment Analysis of the TikTok Application from Reviews on Google Play Store Using the Naïve Bayes Method	Naïve Bayes	Akurasi 83,66%, precision 82,97%, recall 91,97%.	Membuktikan bahwa Naïve Bayes memberikan performa yang baik pada analisis sentimen berbahasa Indonesia.
3	Apriani, Hanif, Oktavianalisti, Monasari, & Winarni (2024)	Sentiment Analysis of Using TikTok as a Learning Media Using the Naïve Bayes Classifiers Algorithm	TF-IDF dan Naïve Bayes	Akurasi 52,27%.	Menjelaskan tahapan analisis sentimen mulai dari preprocessing hingga klasifikasi menggunakan Naïve Bayes.
4	Andrian & Isnain (2024)	Analisis Sentimen Masyarakat Terhadap TikTok Shop di Twitter Menggunakan Metode	Naïve Bayes	Akurasi 78,22%; precision 86%; recall 84%.	Menunjukkan efektivitas Naïve Bayes dalam menganalisis opini publik pada media sosial.

		Naïve Bayes Classifier			
5	Putri, Alfian, Putra, & Mulyo (2024)	IndoBERT Model Analysis: Twitter Sentiments on Indonesia's 2024 Presidential Election	IndoBERT	Model IndoBERT mampu mengklasifikasikan sentimen berbasis transformer pada data Twitter.	Menjadi dasar penggunaan IndoBERT sebagai metode pelabelan otomatis pada penelitian ini.
6	Aras, Yusuf, Ruimassa, Wambrauw, & Pala'langan (2024)	Sentiment Analysis on Shopee Product Reviews Using IndoBERT	IndoBERT	Akurasi mencapai 93%.	Mendukung penggunaan IndoBERT karena memiliki performa tinggi dalam analisis sentimen bahasa Indonesia.
7	Zamsuri & Wileks (2024)	Sentiment Analysis of TikTok Shop Closure Using Naïve Bayes Algorithm and Support	Naïve Bayes dan SVM	Akurasi Naïve Bayes sebesar 89,1%.	Membuktikan bahwa Naïve Bayes masih kompetitif untuk analisis sentimen pada isu yang berkaitan dengan TikTok.

		Vector Machine			
8	Rahmadani dkk. (2022)	TikTok Social Media Sentiment Analysis Using the Naïve Bayes Classifier Algorithm	Naïve Bayes	Akurasi sekitar 80%.	Menjadi salah satu penelitian awal yang menerapkan Naïve Bayes pada data TikTok.
9	Khoerunnisa, Shiddiq, & Nurhayati (2025)	Penerapan Algoritma Naïve Bayes dengan Teknik TF-IDF dan Cross Validation untuk Analisis Sentimen terhadap Starlink	TF-IDF dan Naïve Bayes	Menunjukkan TF-IDF efektif digunakan pada analisis sentimen dengan Naïve Bayes.	Menguatkan pemilihan TF-IDF sebagai metode ekstraksi fitur pada penelitian ini.
10	Suryanti & Prasetyaningrum (2025)	Perbandingan Metode TF-IDF dan Bag of Words dalam	TF-IDF, Bag of Words, Naïve Bayes	TF-IDF memberikan hasil lebih baik dibanding Bag of Words.	Menjadi dasar pemilihan TF-IDF sebagai metode pembobotan kata.

		Analisis Sentimen Diet Kopi Americano di Media Sosial Twitter Menggunakan Naïve Bayes			
11	Wahid, Sanatang, & Andayani (2025)	Performance Comparison of SVM and Naïve Bayes for Indonesian-Language Sentiment Analysis on Free Fire Reviews Using TF-IDF and SMOTE	TF-IDF, SMOTE, Naïve Bayes, SVM	SMOTE meningkatkan performa Naïve Bayes pada dataset yang tidak seimbang.	Mendukung penggunaan SMOTE untuk menangani ketidakseimbangan kelas sebelum proses klasifikasi.
12	Saraswati, Handayani, Umam, & Mustofa (2025)	Sentiment Classification of MyPertamina Reviews	TF-IDF, Naïve Bayes, Logistic	Naïve Bayes memperoleh akurasi 81%.	Menguatkan bahwa Naïve Bayes masih efektif digunakan untuk

		Using Naïve Bayes and Logistic Regression	Regressio n		analisis sentimen pada data teks berbahasa Indonesia.
--	--	---	----------------	--	---

2.2 Landasan Teori

2.2.1 Text Mining

Text mining atau penambangan teks merupakan suatu metode komputasi yang diandalkan untuk menggali informasi bermakna serta mengenali pola-pola tersembunyi dari sekumpulan dokumen atau data yang berwujud teks. Data teks pada umumnya belum tersusun dalam format yang dapat langsung dianalisis, sehingga diperlukan proses pengolahan untuk memperoleh informasi yang relevan. (Kobayashi dkk., 2018) menjelaskan bahwa text mining membantu peneliti menganalisis data teks dalam jumlah besar secara sistematis, sedangkan (Hotho dkk., 2005) menyebut text mining sebagai proses *knowledge discovery from text* untuk menemukan pola bermakna dari kumpulan dokumen, Dengan demikian, *text mining* tidak hanya membaca teks, tetapi juga mengekstraksi informasi penting yang tersembunyi dalam data teks untuk menghasilkan pengetahuan yang bermanfaat.

Dalam penerapannya, *text mining* mencakup beberapa proses pengolahan sebelum data digunakan dalam pemodelan. Tahapan tersebut dapat meliputi pengumpulan data, *preprocessing*, pembentukan representasi fitur, hingga pemodelan. (Hickman dkk., 2022) menegaskan bahwa tahap prapemrosesan memegang peranan yang penting, karena mutu teks yang telah disiapkan akan menentukan proses analisis berikutnya. Setelah tahapan tersebut dilakukan, teks dapat diubah menjadi representasi numerik melalui metode seperti TF-IDF agar selanjutnya dapat diproses oleh algoritma pembelajaran mesin (Weiss dkk., 2005).

Text mining sangat erat kaitannya dengan *Natural Language Processing* (NLP) dan machine learning. NLP memungkinkan komputer untuk menafsirkan dan mengolah bahasa manusia, sementara pembelajaran mesin mengidentifikasi pola dalam teks setelah diubah menjadi bentuk numerik. (Li dkk., 2022) dan (Minaee dkk.,

2022) menjelaskan bahwa perkembangan klasifikasi teks sangat dipengaruhi oleh kemajuan *machine learning* dan *deep learning*. Dalam analisis sentimen, kombinasi text mining, NLP, dan machine learning memungkinkan sistem untuk mengidentifikasi opini positif, negatif, atau netral secara otomatis (Li dkk., 2022; Minaee dkk., 2022)

Penerapan penambangan teks (*text mining*) dalam riset ini difokuskan untuk memproses kumpulan komentar TikTok yang menyoroti aturan kerja dari rumah atau *Work From Home* (WFH) setiap hari Jumat bagi pegawai aparatur sipil negara. Mengingat sifat teks komentar di media sosial yang umumnya ringkas serta penuh dengan ragam bahasa tidak formal, data tersebut wajib melalui rangkaian tahap pembersihan terlebih dahulu sebelum siap diklasifikasikan. Hasil olahan data inilah yang kemudian dijadikan sebagai bahan masukan utama untuk menjalankan pemodelan sentimen berbasis algoritma Multinomial Naïve Bayes (Kumar & Garg, 2020). Melalui tahapan tersebut, *text mining* berfungsi sebagai pondasi krusial dalam mentransformasikan data mentah komentar warganet menjadi format yang terstruktur dan siap dianalisis..

2.2.2 Natural Language Processing (NLP)

Natural Language Processing (NLP adalah salah satu cabang dalam kecerdasan buatan yang mengkhususkan diri pada cara komputer memproses serta memahami bahasa manusia. Melalui NLP, bahasa alami yang digunakan sehari-hari dapat diolah untuk mendukung berbagai keperluan teknis, seperti ekstraksi informasi, klasifikasi teks, hingga analisis sentimen. Sebagaimana dijelaskan oleh (Khurana dkk., 2023), kini telah menjadi disiplin ilmu yang krusial karena kemampuannya dalam memfasilitasi pemrosesan teks secara otomatis untuk beragam tugas tersebut. Pada dasarnya, teknologi ini berperan sebagai penghubung antara kompleksitas bahasa alami dengan kebutuhan algoritma komputasi akan data yang terstruktur agar dapat diproses dengan efisien (Kumar & Garg, 2020).

Proses pengolahan teks dengan NLP umumnya mencakup beberapa tahapan, seperti tokenisasi, normalisasi, *stemming*, penyaringan kata-kata yang tidak signifikan, hingga penyesuaian konteks kalimat. Rangkaian tahapan ini diperlukan agar data teks menjadi lebih siap untuk dianalisis melalui pendekatan *machine learning* ataupun *deep learning*. Dalam hal ini, (Hickman dkk., 2022) menegaskan bahwa tahapan *preprocessing* memegang peranan krusial dalam setiap riset yang memanfaatkan data teks. Lebih lanjut, sifat komentar media sosial yang cenderung singkat, tidak baku, serta kaya akan variasi bahasa membuat penerapan NLP sangat dibutuhkan pada tahap penyiapan data tersebut (Hickman dkk., 2022; Li dkk., 2022).

Pemanfaatan *Natural Language Processing* (NLP) dalam studi ini diandalkan untuk mengelola diskursus komentar TikTok mengenai aturan kerja dari rumah atau *Work From Home* (WFH) hari Jumat bagi aparatur negara. Mengingat gaya bahasa warganet di media sosial yang kerap tidak baku, sarat singkatan, penggunaan emoji, hingga ekspresi emosional yang spontan, diperlukan rangkaian penanganan bahasa yang cermat agar data siap diolah lebih lanjut. Melalui penerapan NLP, teks-teks tersebut disaring serta dinormalisasi, sebelum akhirnya diubah menjadi format representasi numerik yang ideal untuk menunjang proses klasifikasi sentimen menggunakan algoritma Multinomial Naïve Bayes (Minaee dkk., 2022; Singh dkk., 2020).

2.2.3 Analisis Sentimen

Analisis sentimen adalah pendekatan yang dipakai untuk mengenali arah opini atau pandangan dari sebuah teks, lalu mengelompokkannya ke dalam kategori sentimen tertentu seperti positif, negatif, dan netral. Penggunaan metode ini di media sosial bermanfaat untuk memetakan tanggapan masyarakat terhadap suatu isu berdasarkan isi komentar yang dibagikan. (Dina dkk., 2025) menyatakan bahwa komentar di TikTok bisa dianalisis guna memahami kecenderungan emosi serta pandangan pengguna, sementara (Mubaroh dkk., 2026) memanfaatkan komentar dari platform yang sama untuk mengukur respons khalayak melalui tahapan klasifikasi sentimen..

Pelaksanaan analisis sentimen pada data media sosial umumnya melalui beberapa tahapan sistematis, yang meliputi pengumpulan data, *preprocessing*, pelabelan, ekstraksi fitur, klasifikasi, hingga evaluasi. Rangkaian proses ini krusial untuk menyiapkan data teks sebelum masuk ke tahap pemodelan. Khusus pada data TikTok, tahapan pengolahan ini memegang peranan penting mengingat karakteristik komentar pengguna yang cenderung ringkas, tidak baku, serta sering memakai bahasa sehari-hari termasuk singkatan. (Friska Aditia Indriyani dkk., 2023) menerapkan metode *Naïve Bayes* dan SVM untuk analisis sentimen pada data TikTok, sementara (Setiawan dkk., 2023) memanfaatkan pendekatan *deep learning* seperti LSTM dan IndoBERTweet pada ulasan TikTok berbahasa Indonesia. Fleksibilitas ini membuktikan bahwa analisis sentimen sangat adaptif diterapkan pada beragam format data teks yang bersumber dari TikTok..

Penelitian ini menggunakan analisis sentimen guna mengenali arah respons pengguna TikTok terhadap kebijakan *Work From Home* hari Jumat bagi aparatur sipil negara. Mengingat isu ini berkaitan langsung dengan kebijakan publik, tanggapan masyarakat mampu merefleksikan tingkat penerimaan atau penolakan terhadap aturan tersebut, sekaligus mencerminkan pandangan publik terkait efektivitas kerja ASN serta mutu pelayanan yang diberikan. Oleh karena itu, analisis sentimen berperan dalam mengonversi opini yang diunggah pengguna TikTok menjadi informasi yang terstruktur sehingga dapat diteliti secara terarah dan ilmiah.

2.2.4 Media Sosial Tiktok



Gambar 2. 1 Logo Tiktok

TikTok adalah platform media sosial yang berfokus pada konten video berdurasi singkat, lengkap dengan fitur yang memfasilitasi pengguna untuk memproduksi, membagikan, serta menanggapi berbagai macam unggahan. Pemanfaatan TikTok kini telah melampaui fungsi hiburan semata dan bertransformasi menjadi ruang interaksi serta penyaluran aspirasi. Lewat kolom komentar, pengguna dapat menyampaikan respons secara langsung dan spontan terhadap suatu konten atau isu aktual. (Setiawan dkk., 2023) membuktikan bahwa ulasan di TikTok Indonesia dapat dikaji untuk merepresentasikan tanggapan pengguna terhadap layanan tersebut, sementara (Purnamawati dkk., 2023) juga menegaskan bahwa TikTok layak dijadikan objek analisis sentimen karena mampu menghasilkan data teks yang kaya dari ulasan dan opini penggunanya.

Dalam konteks penelitian di Indonesia, TikTok kerap dimanfaatkan sebagai sumber data untuk memetakan opini publik mengenai berbagai isu aktual yang sedang hangat. (Friska Aditia Indriyani dkk., 2023) meneliti sentimen terhadap aplikasi TikTok menggunakan Naïve Bayes dan SVM, sementara (Dina dkk., 2025) meneliti komentar TikTok yang berpotensi menyebabkan depresi dengan pendekatan Naïve Bayes. Hasil penelitian tersebut menunjukkan bahwa komentar TikTok dapat merepresentasikan sikap, emosi, dan respons pengguna secara nyata sehingga layak dianalisis dengan text mining dan analisis sentimen (Dina dkk., 2025; Friska Aditia Indriyani dkk., 2023).

Pemilihan TikTok sebagai wadah pengambilan data dalam studi ini didasari oleh karakteristik platform yang memfasilitasi kebebasan publik dalam mengekspresikan sudut pandang terhadap berbagai isu aktual, termasuk perihal regulasi dari pemerintah. Unggahan video yang membahas aturan WFH bagi pegawai aparatur sipil negara lazimnya dibanjiri oleh ragam reaksi warganet, mulai dari bentuk apresiasi, sanggahan tajam, hingga berbagai tanda tanya kritis menyangkut kebijakan tersebut. Berbekal fenomena itu, himpunan komentar pada konten TikTok yang dikaji menyimpan potensi besar untuk diolah menjadi korpus utama guna memetakan peta kecenderungan sentimen masyarakat terhadap kebijakan *Work From Home* (WFH) hari Jumat bagi ASN (Setiawan dkk., 2023).

2.2.5 Work From Home (WFH) ASN

Pengaturan *Work From Home* (WFH) bagi pegawai aparatur negara merupakan salah satu inovasi penataan sistem kerja yang memberikan fleksibilitas lokasi dalam menunaikan kewajiban kedinasan. Secara yuridis, kerangka aturan mengenai hari serta jam kerja pegawai negeri ini berpedoman pada Peraturan Presiden Republik Indonesia Nomor 21 Tahun 2023 tentang Hari Kerja dan Jam Kerja Instansi Pemerintah dan Pegawai ASN, yang memberlakukan lima hari kerja dalam sepekan sekaligus memberi ruang bagi fleksibilitas pola kerja. Ketentuan tersebut kemudian diperinci secara operasional melalui Surat Edaran Menteri PANRB Nomor 3 Tahun 2026 yang menetapkan komposisi kerja empat hari di kantor (*Work From Office*) dan sehari di rumah (*Work From Home*) setiap hari Jumat bagi instansi pemerintah pusat. Sementara itu, implementasi aturan ini di tingkat instansi daerah diperkuat lewat terbitannya Surat Edaran Mendagri Nomor 800.1.5/3349/SJ Tahun 2026 yang secara khusus mengatur tentang akselerasi transformasi budaya kerja ASN di lingkungan pemerintah daerah.

Di dalam literatur ilmiah, penerapan WFH atau bentuk fleksibilitas kerja pada ASN banyak dibahas karena berpengaruh terhadap efektivitas kerja, koordinasi, dan adaptasi teknologi. (Basri & Hanifah, 2026) menjelaskan bahwa implementasi *Work From Anywhere* (WFA) pada ASN dapat meningkatkan fleksibilitas dan keseimbangan kerja, tetapi tetap menghadapi kendala seperti stabilitas jaringan internet dan koordinasi daring. Selain itu, penelitian tentang fleksibilitas kerja ASN menunjukkan bahwa model kerja jarak jauh dapat berjalan efektif apabila organisasi mampu menyesuaikan sistem kerja, dukungan teknologi, dan evaluasi berbasis hasil. Dengan demikian, WFH ASN bukan hanya kebijakan administratif, tetapi juga bagian dari transformasi budaya kerja dan modernisasi birokrasi yang dapat memunculkan respons publik beragam.

Dalam penelitian ini, kebijakan WFH ASN hari Jumat menjadi konteks penting karena dapat memengaruhi persepsi masyarakat terhadap kinerja ASN dan kualitas pelayanan publik. Komentar masyarakat di TikTok terhadap kebijakan ini berpotensi berisi dukungan, kritik, maupun saran, sehingga relevan dianalisis

menggunakan pendekatan text mining dan analisis sentimen. Oleh sebab itu, WFH ASN digunakan sebagai objek kajian untuk memahami sentimen publik secara lebih terstruktur melalui komentar media sosial.

2.2.6 Web Scrapping

Web scraping atau pengerukan web merupakan suatu teknik komputasi yang diandalkan untuk menghimpun data secara otomatis dari halaman-halaman situs web dengan menggunakan bantuan program atau skrip khusus.(Mustapha dkk., 2024) menjelaskan bahwa teknik ini dapat digunakan untuk mengekstraksi informasi yang relevan dari web sehingga dapat dikumpulkan menjadi dataset untuk keperluan analisis lebih lanjut, Sejalan dengan hal tersebut, (Chrisinta & Simarmata, 2024) mengemukakan bahwa teknik *web scraping* memfasilitasi proses pengumpulan data dari halaman situs secara otomatis, sehingga sangat mendukung berbagai keperluan di ranah *data mining*. Penggunaan teknik ini juga dapat membantu mempercepat proses pengumpulan data serta membuat proses tersebut lebih efisien dan konsisten dibandingkan pengumpulan data secara manual (Hafiz & Sudarmilah, 2023; Prasetyani dkk., 2024).

Dalam penelitian berbasis media sosial, web scraping digunakan untuk mengumpulkan komentar, ulasan, atau opini pengguna yang tersebar di internet. (Hafiz & Sudarmilah, 2023) menunjukkan bahwa web scraping pada portal berita dapat dilakukan secara otomatis untuk memperoleh data yang terstruktur, sedangkan (Chrisinta & Simarmata, 2024) menegaskan bahwa teknik ini sangat membantu dalam proses data mining dan pengolahan informasi. Penelitian ini menggunakan teknik *web scraping* untuk menghimpun data ulasan dari platform TikTok yang membahas kebijakan *Work From Home* hari Jumat bagi kalangan ASN. Data yang sukses terkumpul ini nantinya akan diproses lebih lanjut melalui tahapan *preprocessing*, pelabelan, hingga proses klasifikasi sentimen.

2.2.7 Text Preprocessing

Text preprocessing adalah rangkaian tahapan yang dikerjakan guna mempersiapkan data teks sebelum melangkah ke proses analisis. Kegiatan ini melibatkan pembersihan serta penyeragaman data agar format teks menjadi lebih ideal untuk pengolahan berikutnya. Peran penting tahapan pra-pemrosesan (*preprocessing*) dalam analisis sentimen ditekankan oleh (Khairunnisa dkk., 2021) yang menjelaskan bahwa korpus teks mentah lazimnya masih dipenuhi oleh berbagai gangguan seperti *noise*, singkatan kata, tanda baca, emoji, hingga ragam bahasa nonbaku. Pandangan tersebut diperkuat oleh (Rifaldi dkk., 2023) yang menyebutkan bahwa langkah pembersihan ini bertujuan untuk mengubah data yang tadinya tidak terstruktur menjadi format yang jauh lebih bersih, rapi, dan siap dieksploitasi secara maksimal oleh algoritma pengolahan teks lanjutan.

Pada penelitian ini, *text preprocessing* diaplikasikan guna menyiapkan komentar TikTok sebelum masuk ke tahapan klasifikasi sentimen. Rangkaian pengolahan data tersebut meliputi beberapa langkah, yaitu *cleaning*, *case folding*, *normalization*, *tokenizing*, *stopword removal*, serta *stemming*. Deretan proses ini dimaksudkan untuk menyaring elemen-elemen yang tidak esensial dari data teks sekaligus memperoleh bentuk data yang paling ideal untuk tahapan ekstraksi fitur dan klasifikasi. Penerapan prosedur *preprocessing* yang serupa juga banyak dijumpai dalam berbagai riset analisis sentimen berbahasa Indonesia, sebab terbukti ampuh dalam meredam *noise* dan menyajikan representasi teks yang lebih siap diolah oleh algoritma klasifikasi. Adapun tahapan *text preprocessing* yang dijalankan dalam penelitian ini mencakup:

1. Cleaning

Langkah ini dikerjakan untuk menyingkirkan berbagai karakter atau elemen yang tidak esensial bagi proses analisis, seperti tanda pagar, simbol, emoji, tautan URL, dan *mention*.

2. Case Folding

Case folding adalah proses penyeragaman seluruh huruf dalam data teks dengan cara mengubah semua huruf kapital menjadi huruf kecil. Langkah

ini bertujuan mencegah perbedaan penafsiran pada kata yang sebenarnya sama hanya karena variasi penulisan huruf besar dan kecil, contohnya kata "Baik" dan "baik".

3. Tokenizing

Tokenisasi merupakan tahapan memecah kalimat atau dokumen menjadi bagian-bagian yang lebih ringkas yang dinamakan token. Token tersebut bisa berupa kata, angka, frasa, ataupun tanda baca, menyesuaikan dengan metode yang diterapkan. Sebagai ilustrasi, kalimat “kebijakan wfh asn sangat baik” akan diurai menjadi token “kebijakan”, “wfh”, “asn”, “sangat”, serta “baik”.

4. Normalisasi

Langkah ini dilakukan untuk menerjemahkan berbagai bentuk kosakata tidak baku, singkatan informal, hingga ragam bahasa gaul (*slang*) ke dalam padanan kata standar sesuai kaidah bahasa Indonesia. Sebagai bentuk implementasinya, kosakata seperti "gak" disesuaikan menjadi "tidak", atau "bgus" diubah kembali menjadi "bagus"

5. Stopword Removal

Tahapan ini bertujuan menyaring dan menghilangkan kata-kata di dalam setiap ulasan yang tidak memberikan kontribusi signifikan terhadap proses klasifikasi. Kata-kata tugas seperti "yang", "dan", "di", "dari", hingga "pada" biasanya dibuang dengan memanfaatkan pustaka *stopword* bahasa Indonesia dari NLTK.

6. Stemming

Proses ini berfokus pada pengembalian setiap kata berimbuhan ke bentuk kata asal (*root word*). Sebagai ilustrasi, kata "bekerja", "pekerjaan", serta "pekerja" akan disederhanakan menjadi "kerja". Riset ini memanfaatkan pustaka Sastrawi untuk menangani proses *stemming* teks berbahasa Indonesia.

2.2.8 Pelabelan Sentimen Menggunakan IndoBERT

Koto dkk.,(2020) mendefinisikan IndoBERT sebagai model bahasa pra-latih (*pre-trained language model*) berbasis *Bidirectional Encoder Representations from Transformers* (BERT) yang dikembangkan secara khusus guna mengolah teks berbahasa Indonesia. Berbekal arsitektur *Transformer*, model ini memiliki keunggulan dalam menangkap relasi antarkata secara menyeluruh dengan memerhatikan konteks kalimat dari dua arah sekaligus (*bidirectional contextual representation*). Lebih lanjut, (Supriyadi & Makatita, 2025) mengemukakan bahwa kebolehan tersebut membuat IndoBERT diandalkan dalam beragam penerapan *Natural Language Processing* (NLP), mulai dari klasifikasi teks, analisis sentimen, pengenalan entitas bernama (*named entity recognition*), hingga penjawab otomatis (*question answering*). Kapasitas ini diperoleh berkat kemampuannya dalam menyajikan representasi semantik yang jauh lebih optimal jika dibandingkan dengan pendekatan konvensional.

Penelitian ini memanfaatkan IndoBERT sebagai pendekatan pelabelan sentimen otomatis (*automatic labeling* atau *pseudo labeling*) guna menyematkan kategori positif, negatif, dan netral pada sekumpulan komentar TikTok sebelum tahapan klasifikasi dijalankan. Berdasarkan penjelasan (Koto dkk., 2020), representasi kontekstual yang dimiliki IndoBERT memungkinkan model untuk mencermati unsur negasi, relasi antarkata, serta esensi kalimat secara lebih akurat daripada pendekatan konvensional berbasis leksikon. Alasan utama pemilihan IndoBERT didasarkan pada kemampuannya dalam menghadirkan label yang lebih seragam, meredam unsur subjektivitas yang kerap muncul pada pelabelan manual, sekaligus mendongkrak efisiensi penyusunan perangkat data berlabel yang nantinya diolah melalui ekstraksi fitur TF-IDF serta algoritma *Multinomial Naïve Bayes*.

Penggunaan IndoBERT dalam menganalisis sentimen pada data TikTok telah banyak dibuktikan melalui berbagai riset terdahulu. (Supriyadi & Makatita, 2025) mengaplikasikan model ini untuk menelaah sentimen komentar warganet di TikTok mengenai penggunaan QRIS di Indonesia dan sukses mendapatkan performa

klasifikasi yang konsisten. Di samping itu,(Luthfiani & Hendrawan, 2026) memanfaatkan IndoBERT guna memetakan pandangan publik terhadap digitalisasi UMKM lewat ulasan TikTok, di mana temuan riset tersebut membuktikan keandalan IndoBERT dalam mengelompokkan sentimen positif, negatif, serta netral pada teks berbahasa Indonesia. Tidak hanya itu,(Zaki dkk., 2025) turut menggunakan IndoBERT untuk mengklasifikasikan sentimen ulasan Almaz Fried Chicken di TikTok dengan menggabungkannya bersama teknik *Random Oversampling*, yang hasilnya memperlihatkan bahwa model ini tetap tangguh menjaga performa klasifikasi meskipun dihadapkan pada distribusi data komentar yang tidak seimbang. Berbekal rekam jejak dari berbagai studi tersebut, IndoBERT dinilai sebagai pilihan yang paling tepat untuk menjalankan fungsi pelabelan sentimen, mengingat karakteristik ulasan TikTok yang cenderung ringkas, tidak baku, serta sarat akan konteks khusus..

2.2.9 Term Frequency Inverse Document Frequency (TF-IDF)

Manning dkk.,(2008), menjelaskan bahwa *Term Frequency–Inverse Document Frequency* (TF-IDF) merupakan metode pembobotan yang digunakan untuk menentukan tingkat signifikansi sebuah kata dalam dokumen, dengan cara menimbang frekuensi kemunculannya serta tingkat kelangkaannya dalam total koleksi dokumen. Pendekatan ini merupakan hasil kombinasi antara *Term Frequency* (TF), yang berfungsi menghitung frekuensi kemunculan kata pada dokumen spesifik, dan *Inverse Document Frequency* (IDF), yang berperan menilai seberapa langka kata tersebut di antara seluruh dokumen yang ada. Lebih mendalam,(Aggarwal, 2018) memaparkan bahwa TF-IDF sangat efektif dalam menghasilkan representasi numerik karena mampu memberikan bobot tinggi pada kata-kata yang informatif, sekaligus menekan pengaruh istilah yang terlalu umum namun minim nilai pembeda antar-dokumen. Oleh karena itu, dalam bidang analisis sentimen, TF-IDF kerap diandalkan sebagai instrumen untuk ekstraksi fitur sebelum data diproses lebih lanjut oleh algoritma pembelajaran mesin, seperti Multinomial Naïve Bayes (Khoerunnisa dkk., 2025).

Rumus Term Frequency (TF)

$$TF(t, d) = \frac{f(t, d)}{\sum f(d)} \quad (2.1)$$

Keterangan:

- $TF(t, d)$ = nilai frekuensi kemunculan kata t pada dokumen d .
- $f(t, d)$ = jumlah kemunculan kata t pada dokumen d .
- $\sum f(d)$ = jumlah seluruh kata pada dokumen d .

Rumus Inverse Document Frequency (IDF):

$$IDF(t) = \log \left(\frac{N}{df(t)} \right) \quad (2.2)$$

Keterangan:

- N = jumlah seluruh dokumen.
- $df(t)$ = jumlah dokumen yang mengandung kata t .

Rumus TF-IDF :

$$TFIDF(t, d) = TF(t, d) \times IDF(t) \quad (2.3)$$

Keterangan:

$TFIDF(t, d)$ = bobot akhir kata t pada dokumen d .

2.2.10 Synthetic Minority Over-sampling Technique (SMOTE)

Chawla dkk., (2002) memaparkan bahwa *Synthetic Minority Over-sampling Technique* (SMOTE) adalah metode *oversampling* yang dikembangkan untuk menangani ketimpangan proporsi data antar-kelas melalui penciptaan data sintetis baru pada kelompok minoritas. Pendekatan ini memiliki keunggulan dibandingkan *random oversampling* yang hanya menduplikasi data eksisting, karena SMOTE mampu membentuk data baru lewat proses interpolasi di antara sampel kelas minoritas serta tetangga terdekatnya (*k-nearest neighbors*) (Fernández dkk., 2018).

Mekanisme ini dinilai sangat membantu model agar dapat mengenali karakteristik kelas minoritas dengan lebih optimal, sekaligus meminimalisir kecenderungan bias model terhadap kelas mayoritas. Dalam riset ini, teknik SMOTE diterapkan pada data latih setelah proses pembagian data (*train-test split*), guna mencapai distribusi kelas sentimen yang seimbang sebelum memasuki tahap klasifikasi dengan algoritma Multinomial Naïve Bayes (Wahid dkk., 2025b).

Rumus pembentukan data sintetis pada SMOTE:

$$x_{\text{baru}} = x_i + \lambda(x_{zi} - x_i)$$

Keterangan:

- x_{baru} = data sintetis yang dihasilkan.
- x_i = data pada kelas minoritas.
- x_{zi} = salah satu tetangga terdekat (*nearest neighbor*) dari x_i .
- λ = bilangan acak dengan nilai ($0 \leq \lambda \leq 1$)

2.2.11 Chi-Square Feature Selection

Hokijuliandy dkk., (2023), mendefinisikan *Chi-Square Feature Selection* sebagai teknik penyaringan fitur berbasis statistika yang berfungsi untuk mengukur tingkat keterkaitan antara suatu atribut dengan kelas targetnya. Atribut yang mencatatkan skor *Chi-Square* tinggi dinilai memiliki daya beda yang lebih kuat antarkelas, sehingga layak dipertahankan untuk dilibatkan dalam tahapan klasifikasi. Di samping itu, (Harungguan dkk., 2023) menguraikan bahwa metode ini efektif dalam memangkas atribut-atribut yang kurang esensial, sehingga kerja komputasi menjadi jauh lebih ringkas tanpa mengorbankan kualitas performa klasifikasi. Temuan (Ernayanti dkk., 2023) juga membuktikan bahwa integrasi antara pembobotan TF-IDF, *Chi-Square Feature Selection*, dan *Multinomial Naïve Bayes* mampu mendongkrak ketepatan klasifikasi sentimen jika dibandingkan dengan pemanfaatan TF-IDF mandiri tanpa adanya seleksi fitur. Berdasarkan alasan tersebut, riset ini mengaplikasikan *Chi-Square Feature Selection* sesuai tahap ekstraksi fitur

TF-IDF demi menyaring variabel-variabel yang paling esensial sebelum data diklasifikasikan via algoritma *Multinomial Naïve Bayes*.

Rumus *Chi-Square*:

$$\chi^2 = \frac{N(AD - BC)^2}{(A + C)(B + D)(A + B)(C + D)}$$

Keterangan:

- χ^2 = nilai Chi-Square.
- **A** = jumlah dokumen yang mengandung fitur dan termasuk dalam kelas tertentu.
- **B** = jumlah dokumen yang mengandung fitur tetapi tidak termasuk dalam kelas tersebut.
- **C** = jumlah dokumen yang tidak mengandung fitur tetapi termasuk dalam kelas tersebut.
- **D** = jumlah dokumen yang tidak mengandung fitur dan tidak termasuk dalam kelas tersebut.
- **N** = jumlah seluruh dokumen.

2.2.12 Multinomial Naïve Bayes

Zulfikar dkk., (2023) mengemukakan bahwa *Multinomial Naïve Bayes* adalah algoritma klasifikasi berlandaskan probabilitas yang sangat populer dalam bidang analisis sentimen, sebab algoritma ini handal dalam mengolah data teks dengan memanfaatkan sebaran frekuensi kemunculan kata di dalam suatu dokumen. Lebih lanjut (Ukasyah dkk., 2021) menerapkan algoritma Naïve Bayes pada sistem deteksi login dengan pendekatan *online incremental learning*. Sementara itu, (Novriani dkk., 2023) memanfaatkan metode serupa guna memprediksi tingkat kelayakan gerbong kereta terbuka. Berbagai temuan riset tersebut membuktikan bahwa *Naïve Bayes* merupakan pendekatan yang fleksibel dan dapat diandalkan untuk menyelesaikan beragam persoalan klasifikasi, termasuk pemilahan teks dalam ranah analisis sentimen.

Algoritma *Multinomial Naïve Bayes* beroperasi dengan menerapkan Teorema Bayes serta dilandasi oleh asumsi dasar bahwa seluruh fitur yang digunakan saling bebas atau independen. Karakteristik asumsi ini menjadikan proses komputasi yang dibutuhkan tergolong sederhana dan efisien, namun tetap sanggup menyajikan performa yang memuaskan dalam ranah klasifikasi teks. Di samping itu, (Gerliandeva dkk., 2024) menguraikan bahwa *Multinomial Naïve Bayes* mampu menunjukkan kinerja yang optimal manakala disandingkan dengan ekstraksi fitur TF-IDF serta seleksi atribut Chi-Square. Studi tersebut mengungkapkan bahwa perpaduan antara TF-IDF, N-Gram, SMOTE, Chi-Square, dan *Multinomial Naïve Bayes* sukses mencatatkan tingkat akurasi mencapai 94% serta nilai AUC sebesar 100% pada skenario konfigurasi terbaiknya.

Penelitian ini memanfaatkan algoritma *Multinomial Naïve Bayes* guna mengelompokkan kategori sentimen pada ulasan TikTok. Sebelum korpus teks dieksekusi ke dalam model klasifikasi, data tersebut wajib melewati alur penanganan komprehensif yang mencakup pra-pemrosesan teks, anotasi label otomatis memakai IndoBERT, ekstraksi representasi kata lewat TF-IDF, penanganan ketimpangan kelas via SMOTE, serta seleksi atribut menggunakan Chi-Square. Efektivitas penggabungan Chi-Square dengan *Naïve Bayes* ini didukung oleh temuan (Harungguan dkk., 2023) yang menilai bahwa teknik tersebut mampu mendongkrak performa pemodelan berkat penyaringan variabel yang tidak signifikan. Di samping itu, studi dari (Wibawa & Cokorda, 2023) memperlihatkan bahwa penerapan *Multinomial Naïve Bayes* berbalut pembobotan TF-IDF pada analisis sentimen berbahasa Bali sukses mencetak akurasi 91,5%, presisi 92,3%, *recall* 91,13%, serta *F1-score* 91,38%, yang menegaskan kapabilitas algoritma ini dalam mengolah data teks. Tidak hanya itu, (Ayomi & Dewi, 2023) turut membuktikan bahwa perpaduan antara SMOTE dan *Multinomial Naïve Bayes* efektif meningkatkan efektivitas klasifikasi pada data media sosial yang mengalami ketimpangan distribusi kelas. Berangkat dari berbagai landasan tersebut, algoritma ini dijatuhkan sebagai pilihan utama karena menawarkan proses komputasi yang efisien, kemudahan dalam penerapan teknis, serta rekam jejak performa yang teruji solid untuk pengolahan teks berbahasa Indonesia..

Rumus Teorema Bayes:

$$P(C|X) = \frac{P(X|C) \times P(C)}{P(X)} \quad (2.4)$$

Keterangan:

- $P(C|X)$ = probabilitas data (X) termasuk ke dalam kelas (C).
- $P(X|C)$ = probabilitas data (X) jika diketahui berada pada kelas (C).
- $P(C)$ = probabilitas awal (*prior probability*) kelas.
- $P(X)$ = probabilitas kemunculan data.

Prior probability atau probabilitas awal memegang peranan krusial sebagai salah satu elemen pembentuk dalam komputasi Teorema Bayes. Besaran nilai ini merepresentasikan persentase kemunculan masing-masing kelas yang dihitung berdasarkan total keseluruhan data latih. Perhitungan probabilitas *prior* tersebut dapat diselesaikan melalui rumusan yang tertera pada Persamaan (2.5).

Rumus Prior Probability

$$P(v_j) = \frac{|doc_j|}{|training|} \quad (2.5)$$

Keterangan :

- $P(v_j)$ = probabilitas prior dari kelas v_j
- $|doc_j|$ = jumlah dokumen pada kelas v_j
- $|training|$ = jumlah seluruh dokumen pada data pelatihan.

Di dalam kerangka kerja *Multinomial Naïve Bayes*, nilai *likelihood* dimanfaatkan guna mengukur peluang kemunculan suatu istilah atau kata di dalam tiap-tiap kelas. Proses komputasi ini menerapkan teknik *Laplace Smoothing* guna mengantisipasi kemungkinan nilai probabilitas menjadi nol sekiranya ada kata yang tidak ditemukan di dalam data latih. Adapun rumusan matematis untuk menghitung *likelihood* tersebut dapat dilihat melalui persamaan berikut:.

Rumus Likelihood :

$$P(t_i|c) = \frac{N_{ic} + \alpha}{N_c + \alpha|V|} \quad (2.6)$$

Keterangan:

- $P(t_i|c)$ = probabilitas kemunculan kata t_i pada kelas (c).
- N_{ic} = jumlah kemunculan kata t_i pada kelas (c).
- N_c = jumlah seluruh kata pada kelas (c).
- α = parameter *Laplace Smoothing*.
- $|V|$ = jumlah seluruh kosakata (*vocabulary*).

Berikutnya, peluang akhir atau probabilitas posterior dari suatu dokumen terhadap masing-masing kelas dikalkulasikan dengan menggunakan persamaan *Multinomial Naïve Bayes* sebagai berikut.

Rumus Multinomial Naïve Bayes:


$$P(c|d) \propto P(c) \prod_{i=1}^n P(t_i|c)^{f_i} \quad (2.7)$$

Keterangan:

- $P(c|d)$ = probabilitas dokumen (d) termasuk ke kelas (c).
- $P(c)$ = probabilitas awal kelas.
- $P(t_i|c)$ = probabilitas kemunculan kata ke-(i) pada kelas (c).
- (f_i) = frekuensi kemunculan kata ke-(i) pada dokumen
- n = jumlah kata (*term*) atau fitur yang digunakan dalam proses klasifikasi.

2.2.13 Cross-Industry Standard Process for Data Mining (CRISP-DM)

Kerangka kerja metodologis yang paling sering diandalkan sebagai pedoman dalam pengerjaan riset berbasis penambangan data adalah *Cross-Industry Standard Process for Data Mining* atau yang lazim disingkat CRISP-DM. Pendekatan ini menyediakan panduan tahapan yang terstruktur secara sistematis dan komprehensif, meliputi fase pemahaman bisnis (*business understanding*), penelaahan data (*data understanding*), penyiapan data (*data preparation*), pemodelan (*modeling*), evaluasi (*evaluation*), hingga tahap penyajian hasil akhir (*deployment*) (Wirth & Hipp, 2000).



Gambar 2. 2 Tahapan CRISP-DM

CRISP-DM terdiri atas enam tahapan utama sebagai berikut:

1. **Business Understanding**

Tahap ini berfokus pada upaya memahami latar belakang permasalahan serta merumuskan tujuan utama dari penelitian yang dilakukan

2. **Data Understanding**

Tahap ini berkaitan dengan proses pengumpulan data sekaligus mengenali karakteristik, pola, serta kondisi awal dari data yang akan digunakan.

3. **Data Preparation**

Tahap ini mencakup proses pembersihan, penyesuaian, dan penyiapan data agar memiliki format yang ideal sebelum dimasukkan ke dalam tahapan pemodelan.

4. **Modeling**

Tahap ini adalah proses merancang dan membangun model analisis dengan menerapkan algoritma machine learning yang telah ditentukan sebelumnya.

5. **Evaluation**

Tahap Tahap ini melibatkan pengujian dan pengukuran kinerja model yang telah dibangun dengan menggunakan metrik evaluasi yang relevan untuk memastikan kualitas hasil prediksi.

6. **Deployment**

Tahap menyajikan atau memanfaatkan hasil analisis sesuai dengan tujuan penelitian. *Deployment* tidak selalu berupa pembangunan aplikasi, tetapi dapat berupa penyajian hasil dalam bentuk laporan, tabel, grafik, atau informasi penelitian.

Dalam penelitian ini, CRISP-DM digunakan sebagai kerangka penyusunan alur analisis sentimen komentar pada satu video TikTok mengenai kebijakan WFH hari Jumat bagi ASN. Tahap *Data Preparation* meliputi *text preprocessing*, pelabelan otomatis menggunakan IndoBERT, *filtering confidence score*, TF-IDF, SMOTE, dan Chi-Square. Tahap *Modeling* memanfaatkan algoritma *Multinomial Naïve Bayes* sebagai model utama untuk mengklasifikasikan sentiment, sedangkan tahap *Evaluation* menggunakan *Confusion Matrix* serta metrik performa yang mencakup akurasi (*accuracy*), presisi (*precision*), *recall*, dan *F1-score*. Tahap *Deployment* diwujudkan melalui penyajian hasil klasifikasi dan evaluasi dalam laporan penelitian.

2.2.14 **Evaluasi Model**

Tundo & Rachmawati, (2024), mengemukakan bahwa evaluasi model memegang peranan penting untuk mengukur sejauh mana kehandalan suatu algoritma dalam menjalankan tugas klasifikasi, yakni dengan cara membandingkan label hasil prediksi terhadap kelas aktualnya. Salah satu instrumen pengujian yang lazim dimanfaatkan adalah *Confusion Matrix*, yakni sebuah tabel matriks yang menyajikan perbandingan antara kelas riil dengan kategori tebakan model sehingga ragam kesalahan maupun keberhasilan klasifikasi pada masing-masing kelas dapat teridentifikasi secara jelas. Lebih lanjut, (Nadira dkk., 2023) menjelaskan bahwa

luaran dari *Confusion Matrix* tersebut dapat diolah lebih jauh guna mendapatkan parameter pengukuran kinerja model, seperti akurasi (*accuracy*), presisi (*precision*), *recall*, dan *F1-score*. Pada penelitian ini, tahap evaluasi diterapkan pada tiga kategori sentimen sekaligus—yakni positif, negatif, dan netral—dengan mengandalkan *Confusion Matrix* serta keempat metrik pengukuran performa tersebut.

Tabel 2. 2 Confusion Matrix Klasifikasi Multikelas

		Nilai Prediksi		
		Positif	Negatif	Netral
Nilai Aktual	Positif	A	B	C
	Negatif	D	E	F
	Netral	G	H	I

Keterangan:

A, E, I = jumlah data yang berhasil diklasifikasikan dengan benar.

B, C, D, F, G, H = jumlah data yang salah diklasifikasikan ke kelas lain.

Rumus Accuracy:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN'}$$

Rumus Precision:

$$Precision = \frac{TP}{TP + FP'}$$

Rumus Recall:

$$Recall = \frac{TP}{TP + FN'}$$

Rumus F1-Score:

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall}.$$


Keterangan:

- TP (True Positive) = jumlah data yang diprediksi benar sebagai kelas positif.
- TN (True Negative) = jumlah data yang diprediksi benar sebagai kelas negatif.
- FP (False Positive) = jumlah data yang diprediksi positif tetapi sebenarnya bukan kelas tersebut.
- FN (False Negative) = jumlah data yang diprediksi bukan kelas tersebut tetapi sebenarnya termasuk kelas tersebut.
- Precision = tingkat ketepatan model dalam mengidentifikasi suatu kelas.
- Recall = tingkat kemampuan model dalam menemukan seluruh data pada suatu kelas.

Evaluasi kinerja model dalam riset ini yang meliputi parameter akurasi (*accuracy*), presisi (*precision*), *recall*, serta *F1-score* mengandalkan teknik rerata makro (*macro average*). Lewat penerapan cara tersebut, masing-masing kelas sentimen, baik itu positif, negatif, maupun netral, mendapatkan porsi bobot kontribusi yang sama besar sepanjang proses penghitungan performa model berjalan.

2.3 Kerangka Pemikiran

Alur logis serta keterkaitan fungsional antarvariabel yang ditelaah dalam studi ini digambarkan melalui kerangka pemikiran, yang disusun secara terstruktur guna menjawab seluruh rumusan masalah yang ada. Secara garis besar, riset ini bertopang pada empat fondasi utama yang meliputi *Indicator*, *Proposed Method*, *Objective*, serta *Measurement*, sebagaimana dijabarkan secara visual lewat **Gambar2.2**.



Gambar 2. 3 Kerangka Pemikiran

Berdasarkan **Gambar 2.3**, komponen *Indicator* dalam penelitian ini berwujud sekumpulan komentar warganet pada salah satu konten video TikTok yang mendiskusikan kebijakan *Work From Home* (WFH) hari Jumat bagi kalangan Aparatur Sipil Negara (ASN). Komentar-komentar tersebut dikategorikan sebagai data teks nir-struktur yang sarat akan ragam bahasa informal, singkatan, kosakata nonbaku, serta berbagai unsur *noise*. Oleh sebab itu, sebelum melangkah ke tahap analisis inti, rangkaian data tersebut wajib melalui prosedur pemrosesan pendahuluan terlebih dahulu.

Pada bagian *Proposed Method*, alur pengelolaan data komentar dieksekusi secara berurutan melalui tahap pra-pemrosesan teks seperti *cleaning*, *case folding*, normalisasi, *tokenizing*, *stopword removal*, dan *stemming* untuk mendapatkan korpus yang bersih. Selanjutnya, anotasi sentimen dilakukan secara otomatis menggunakan model IndoBERT via *pseudo-labeling* dengan ambang batas *confidence score* 0,90 agar hanya data bervalidasi tinggi yang lolos, lalu ditransformasikan ke bentuk numerik melalui pembobotan TF-IDF. Guna mengoptimalkan data, teknik SMOTE dikerahkan untuk mengatasi ketimpangan kelas, sementara seleksi fitur terbaik dilakukan menggunakan metode Chi-Square. Sebagai fase penutup, proses pengelompokan sentimen dieksekusi dengan menerapkan algoritma Multinomial Naïve Bayes.

Bagian *Objective* dipusatkan pada pengelompokan ragam komentar warganet ke dalam tiga klasifikasi sentimen utama, yaitu positif, negatif, serta netral. Hasil keluaran

dari tahapan pemodelan tersebut selanjutnya difungsikan untuk memetakan sekaligus membaca arah kecenderungan opini pengguna yang terkandung dalam ulasan video TikTok yang menjadi fokus pengamatan.

Komponen *Measurement* dijalankan dengan mengukur performa model melalui bantuan *Confusion Matrix*. Evaluasi ini mencakup penghitungan nilai akurasi (*accuracy*), presisi (*precision*), *recall*, serta *F1-score* guna menilai sejauh mana tingkat kehandalan model dalam mengklasifikasikan komentar ke dalam masing-masing kategori sentimen secara tepat

.